

Original document

SIGNAL PROCESSOR FOR DISCRIMINATING STEADY STATE AND UNSTEADY STATE

Publication number: JP2000266570

Publication date: 2000-09-29

Inventor: HORIBE KOJI

Applicant: OMRON TATEISI ELECTRONICS CO

Classification:

- international: G05B23/02; G01D21/00; G05B23/02; G01D21/00; (IPC1-7): G01D21/00; G05B23/02

- european:

Application number: JP19990068346 19990315

Priority number(s): JP19990068346 19990315


View INPADOC patent family

Report a data error here

Abstract of JP2000266570

PROBLEM TO BE SOLVED: To provide a signal processor for discriminating the steady state and the unsteady state which enables free expansion of a steady range by increasing the number of feature quantities.

SOLUTION: This signal processor samples a state signal to be processed to perform a buffering while sequentially updating a specified number of sample values with a delay part 4 plus a buffer 5 to determine multiple kinds of feature vectors from a plurality of sample values with a feature quantity calculating part 6. A group of feature vectors obtained is processed by a self organizing device 8 and a group of reference vectors and a pattern thereof are calculated to be preserved in a memory. The group of feature vectors calculated based on the newest state signal is compared to compute with the group of reference vectors preserved and the reference vector pattern by a distance calculating part 9 to calculate the degree of analogy between the group of the newest feature vectors, the group of reference vectors and the reference vector pattern. A comparison judgment part 10 binaries the degree of analogy based on a threshold and



determines whether the newest state signal
is steady or unsteady to output the results.

Data supplied from the *esp@cenet* database - Worldwide

(19) 日本国特許庁 (J P)

(12) 公開特許公報 (A)

(11) 特許出願公開番号

特開2000-266570

(P2000-266570A)

(43) 公開日 平成12年9月29日 (2000.9.29)

(51) Int.Cl. ⁷	識別記号	F I	テーム(参考)
G 0 1 D 21/00		G 0 1 D 21/00	Q 2 F 0 7 6
G 0 5 B 23/02	3 0 2	G 0 5 B 23/02	3 0 2 W 5 H 2 2 3

審査請求 未請求 請求項の数 3 O L (全 13 頁)

(21) 出願番号 特願平11-68346

(22) 出願日 平成11年3月15日 (1999.3.15)

(71) 出願人 000002945

オムロン株式会社

京都府京都市右京区花園土堂町10番地

(72) 発明者 堀部 剛治

京都府京都市右京区花園土堂町10番地

オムロン株式会社内

(74) 代理人 100092598

弁理士 松井 伸一

Fターム(参考) 2F076 BA11 BD11 BE03 BE04 BE05

BE08 BE13

5H223 AA01 AA15 CC08 DD03 EE02


EE06 FF06

(54) 【発明の名称】 定常状態と非定常状態を弁別する信号処理装置

(57) 【要約】

【課題】 特徴量の数を増やすことにより定常範囲を自由に広げることができる定常状態と否定状態を弁別する信号処理装置を提供すること

【解決手段】 処理対象である状態信号をサンプリングし、遅延部4+バッファ5により所定数のサンプル値を逐次更新しながらバッファリングし、特徴量計算部6で複数のサンプル値から複数種類の特徴ベクトルを求め、得られた特徴ベクトル群を自己組織化装置8で処理して参照ベクトル群とそのパターンを計算しメモリに保存する。最新の状態信号に基づいて計算した特徴ベクトル群と保存されている参照ベクトル群および参照ベクトルパターンとを距離計算部9で比較演算し、最新の特征ベクトル群と参照ベクトル群および参照ベクトルパターンとの類似度を計算する。比較判定部10では、類似度をしきい値に基づいて2値化して、最新の状態信号が定常状態か非定常状態かを弁別して出力する。



【特許請求の範囲】

【請求項 1】 処理対象である状態信号を適当な間隔でサンプリングし、適当な個数のサンプル値を逐次更新しながらバッファリングし、そのバッファリングされた複数のサンプル値から複数種類の特徴ベクトルを逐次計算する特徴ベクトル計算機能と、その計算された特徴ベクトル群を自己組織化アルゴリズムにより逐次処理して参照ベクトル群とそのパターンを計算し、求めた参照ベクトル群と参照ベクトルパターンとを逐次更新しながらメモリに保存する機能と、最新の状態信号に基づいて計算した前記特徴ベクトル群と前記メモリに保存されている参照ベクトル群および参照ベクトルパターンとを比較演算することで、最新の前記特徴ベクトル群と前記参照ベクトル群および参照ベクトルパターンとの類似度を計算する類似度計算機能と、その計算された前記類似度が所定の基準に基づいて 2 値化することで、最新の状態信号が定常状態を示しているか非定常状態を示しているかを弁別して出力する機能を備えたことを特徴とする定常状態と非定常状態を弁別する信号処理装置。

【請求項 2】 最新の状態信号に基づいて計算された特徴ベクトル群が、それまでの定常状態では生じていなかった新規な特徴ベクトルを含んでいた場合、非定常状態に変化したものと弁別するようにしたことを特徴とする請求項 1 に記載の定常状態と非定常状態を弁別する信号処理装置。

【請求項 3】 最新の特徴ベクトルと自己組織化された前記参照ベクトル群とのユークリッドノルムを計算し、その中の最小値を定常状態であるか非定常状態であるかを判定する指標として用いることを特徴とする請求項 1 に記載の定常状態と非定常状態を弁別する信号処理装置。

【発明の詳細な説明】

【0001】

【発明の属する技術分野】 本発明は、各種プラントや設備などの状態を監視して故障などによる非定常状態の発生を的確に検出する技術に関し、特に、定常状態と非定常状態を弁別する信号処理装置に関する。

【0002】

【従来の技術】 さまざまな分野で次のようなセンシングシステムが実用されている。監視しようとする対象にセンサを取り付け、温度や圧力などの各種の物理量を電気信号に変換し、そのセンサ出力の時間的な変化を監視することで対象の異常状態とか特殊状態を検出する。

【0003】 定常状態におけるセンサ出力（状態信号）の電気的性質が既知の状態に安定しているのであれば、その状態から外れる非定常状態を弁別することは簡単な信号処理で実現できる。しかし、定常状態での状態信号の電気的性質が特定できない対象も多く、その場合は、状態信号の時間的な変化を監視することで定常状態を的確

に把握し、その定常状態から逸脱する変化を的確に検出することになる。これは簡単なことではなく、さまざまに工夫した信号処理技術が提案されている。代表的なものとして特開平 6-109498 号公報に開示された「非定常および異常状態の検出装置」がある。

【0004】

【発明が解決しようとする課題】 しかしながら、特開平 6-109498 号に開示された技術では、プラントのある種の観測信号の時系列データを階層型ニューラルネットワーク型の自己回帰モデルで近似し、観測データを非線形データに変換する。この自己回帰モデルを異なる構造で少なくとも 2 つ用意し、これらから得られる非線形データの差を観測し、あるしきい値以上になると、定常から非定常に変化したと判断する。つまり、実際に測定される観測信号から階層型ニューラルネットワークを用いて、一連の時系列データを非線形変換することで特徴量を抽出し、それらの変化を監視していると言える。

【0005】 しかしながら、このような階層型ニューラルネットワークによる特徴量の抽出は、その性質から以下のような問題点がある。

(a) 何層で、ニューロン数がいくつの構造にすれば良いかが判らない。また、中間層のニューロン数が異なる構造のニューラルネットワークをいくつも用意しなければならない。

(b) ニューラルネットワークで得られた特徴量はどんな特徴を示しているのか、第三者に対して説明しにくい。

(c) 定常である範囲を大きくとりたい時には多くの特徴量を計算する必要があるが、このような場合、多数のニューラルネットワークが必要となり、複雑になる。

【0006】 本発明は、上記した背景に鑑みてなされたもので、その目的とするところは、上記した従来技術の問題点、つまり第三者に対する説明のしにくさとか、ニューラルネットワークをいくつも用意しなければならない手間や複雑さなどを解決し、特徴量の数を増やすことにより定常範囲を自由に広げることができるようにした信号処理装置を提供することを目的とする。

【0007】

【課題を解決するための手段】 上記した目的を達成するために、本発明に係る定常状態と非定常状態を弁別する信号処理装置は、以下の処理・機能を実現するように構成した。

(1) 処理対象である状態信号を適当な間隔でサンプリングし、適当な個数のサンプル値を逐次更新しながらバッファリングする。

(2) バッファリングされた複数のサンプル値から複数種類の特徴ベクトルを逐次計算する。

(3) 計算された特徴ベクトル群を自己組織化アルゴリズムにより逐次処理して参照ベクトル群とそのパターンを計算し、求めた参照ベクトル群と参照ベクトルパター

ンとを逐次更新しながらメモリに保存する。

(4) 最新の状態信号に基づいて計算した前記特徴ベクトル群と前記メモリに保存されている参照ベクトル群および参照ベクトルパターンとを比較演算することで、最新の前記特徴ベクトル群と前記参照ベクトル群および参照ベクトルパターンとの類似度を計算する。

(5) 前記類似度が所定の基準に基づいて2値化することで、最新の状態信号が定常状態を示しているか非定常状態を示しているのかを弁別して出力する。

【0008】そして、より好ましくは、請求項1に記載の信号処理装置であって、最新の状態信号に基づいて計算された特徴ベクトル群が、それまでの定常状態では生じていなかった新規な特徴ベクトルを含んでいた場合、非定常状態に変化したものと弁別することである(請求項2)。

【0009】また、請求項1に記載の信号処理装置であって、最新の特徴ベクトルと自己組織化された前記参照ベクトル群とのユークリッドノルムを計算し、その中の最小値を定常状態であるか非定常状態であるかを判定する指標として用いるようにしてもよい(請求項3)。

【0010】本発明によれば、定常状態のときの複数種の特徴ベクトルに基づいて自己組織化学習をし、定常状態の特徴ベクトルのパターンを求め、参照ベクトル群・参照ベクトルパターンをメモリに記憶保持させる。自己組織化することでグループ化され、定常状態であれば、比較的近い特徴ベクトルとなる。そこで、定常状態のときの特徴ベクトルのパターンを複数用意しておく、未知の特徴ベクトルが定常状態によるものである場合には、あらかじめ学習し用意していたものと比較的近いものとなる。これに対し、非定常状態が発生した場合の特徴ベクトルは、用意したものとは異なる特徴を有するはずであるので、距離(類似度)が大きく離れることになる。そこで、類似度の大/小から定常状態/非定常状態を弁別できる。

【0011】つまり、定常状態で自己組織化させて得られた特徴を基にして、判定対象の特徴を比較し、大きく異なれば非定常状態と判定できる。そして、自己組織化学習することにより、個々の特徴量は第三者に説明しやすいものとなり、また、処理も簡単となる。そして、特徴量の数を増やすことにより定常範囲を自由に広げることができる。さらに、高次元の入力に対しても低次元空間に写像するので、理解しやすく扱いが容易となる。

【0012】

【発明の実施の形態】本発明を適用する対象としては、さまざまなアプリケーションが考えられるが、ここでは防犯用ドア開閉センサに関して説明する。よく知られているように、室内のドア開閉を検知するセンサに、圧力センサを用いている防犯システムがある。これは例えば、実用新案第3039783号「自主警備システム」などはその典型である。

【0013】このような用途に用いられる圧力センサは、ドア開閉という微小圧力を検出するため高感度となっている。このため、それ以外の原因で発生する圧力変動が定常的に混入する。その原因としては、①エアコン通風孔からの風や窓をたたく風など、風による圧力変化、②人の動きによって空気が攪乱されることによる圧力変化、③日光やエアコンなどの熱源からの温度変化で起こる空気の対流による圧力変化、④壁をたたくななどの衝撃による圧力変化、⑤ビル設備などで建物全体を陽圧に保っているために空気の流れが発生することによる圧力変化などが考えられる。

【0014】これらの圧力変動は、圧力センサの出力である電圧波形にも現れ、ベースラインが変動するゆらぎノイズが定常的に観測される。このような状況でドア開閉動作による圧力変化は電圧波形として振幅変化がノイズよりも多少は大きく出力されるものの、ドア開閉動作が弱かったり、ノイズが時として大きくなった場合、従来の振幅レベルを特徴量とし、振幅レベルが基準値を超えたときに非定常と判定するようなしきい値判定では誤って判定してしまうおそれがある。

【0015】したがって、ドア開閉を正しく判定するには、定常的に混入するノイズからドア開閉という非定常な信号を検出する方法が必要となる。また、ゆらぎノイズの周波数とドア開閉時の信号の周波数はほぼ同一の帯域に存在するため、バンドパスフィルタなどの前処理ではゆらぎノイズは除去できない。

【0016】図1は、本発明に係る信号処理装置の典型的な構成の一実施の形態を示している。この構成で最も特徴的な構成要素は特徴量計算部6と自己組織化装置8であり、これについての詳細な説明は後で述べることにし、図1の各構成要素について順を追って、得られる信号波形を図示しながら説明する。

【0017】**センサ1

まず、状態信号を検出するためのセンサ1がある。このセンサ1は一般的に用いられているものであれば何でも良く、本形態ではドア開閉に伴う圧力変動を検出することから圧力センサを用いている。そして、この圧力センサとしては、各種のものをを用いることができるが、ドア開閉時の圧力変化の特徴をとらえ効率よく状態信号を検出するためには、例えば図2に示すような構造のものをを用いることができる。

【0018】すなわち、圧力センサ1は、ステム1aとキャップ1bを互いの開放面側を接合して構成されるパッケージ1c内にセンサチップ1dを装着する。センサチップのダイヤフラム1eの両面には、ステムに設けた測定圧力導入管1fと、キャップに設けた参照圧力導入管1gを介してそれぞれ導入される圧力がかかる。ここで、参照圧力導入管1g内にフィルタ1hを設置し、参照圧側の圧力応答性を遅くする。フィルタ1hは、例えば多孔質材料から構成してもよいし、オリフィスのよう

に構成してもよい。

【0019】このように構成すると、室内の空気の圧力が、フィルタ1hを通過した後の空気となってセンサチップ1dに伝わるようになっている。そして、フィルタ1hは圧力の急峻な変化は伝わらず、緩やかな変化が伝わるという性質を持つため、ドア開閉等により室内の圧力が急峻に変化した場合には、センサチップ1dのダイヤフラム1eの両面（測定圧側と参照圧側）で圧力変化の応答速度が異なり、この差に応じた信号がセンサ出力となって出現する。

【0020】一方、温度変化や大気圧の変化等の緩やかな圧力変化の場合には、フィルタ1hの有無に関係なくその変化が伝わるので、ダイヤフラム1eの両面で均衡がとれる。つまり、センサ出力に変化がなく、係る環境変化に対する影響を可及的に抑制することができる。

【0021】係る構成の圧力センサを用いると、定常状態での変化が少なくなるとともに、ドアの開閉に伴う信号変化が大きくなるので比較的定常状態と非定常状態を弁別しやすくなる点で好ましいが、この圧力センサ1を用いても定常状態で完全にセンサ出力が直線（振動0）とすることは困難である。

【0022】また、本発明では、状態信号を検出するセンサ1として圧力センサを用いた場合、上記のような構成のものに限ることはなく、各種の圧力センサを用いることができるのは言うまでもない。そして、次段のその圧力センサ1の出力をトランスデューサ2に与えるようになっている。

【0023】**トランスデューサ2と状態信号
トランスデューサ2は、センサ1の物理的変化を電気信号に変換し、それを増幅する回路である。なお、センサ1とトランスデューサ2が一体化されている場合もある。

【0024】図3に示される波形は、図1におけるトランスデューサ2の出力より得られた圧力信号の1例である。この信号が前述の状態信号である。測定した場所は密閉された会議室（大きさ11×20×2.7m、容積130m³）である。そして、測定条件としては、測定時間は約4.3秒で、信号は2.5[V]を中心にして、0から5[V]までがフルスケールとなっている。また、約4.3秒の間にドア開閉を1回だけ行った。また、測定時、会議室は空調が働いており、図3に示すように、センサ出力に基づく状態信号の波形は、空調に伴う風などの影響を受けて圧力変動が激しく、振幅レベルのしきい値処理や、単純に波形をみただけでは、どの時点でドア開閉による圧力変化があったのかは明瞭でない。

【0025】また、図4(a)は、図3の状態信号の周波数スペクトラムである。サンプリング周波数を100Hzとしたので50Hzまでの帯域となっている。図4(b)は、図3の波形でドア開閉による圧力変化付近を拡大したものである。3.8秒付近の点線で囲った領域が

ドア開閉による圧力変化を示している。すなわち、実験では、ドア開閉の時点を知るために、ドア付近に光電センサを設置してドア開閉があった瞬間の時刻を検出するようにしており、その時刻が3.8秒付近であったため、点線で囲む領域がドア開閉に伴う出力信号といえる。そして、点線で囲った領域の波形とその前後の時刻の波形とを比べると、ドア開閉時の変化に類似したゆらぎノイズが観測されていることが判る。

【0026】状態信号の前処理部3

10 上記のトランスデューサ2からの出力信号は、前処理部3に与えられる。この前処理部3の機能は、後述の特徴量計算部6で演算を行う前の信号波形に対する信号処理である。具体的には、アナログフィルタやA/D変換器などの回路などで構成され、不要な情報をできるだけカットするようにしている。そして、本実施の形態では、トランスデューサ2の直後にA/D変換を行っており、その後にデジタルフィルタの処理をしている。なお、係るA/D変換とフィルタの前後の順はどちらでも良い。そして、フィルタは、カットオフ周波数が10Hzのローパスフィルタを用いた。

20 【0027】図5が、図3に示す状態信号に対して前処理を行った後の波形図であり、図6(a)はその前処理後の波形図の周波数スペクトラム、同図(b)はドア開閉による圧力変化の拡大部をそれぞれ示している。前処理後の図6(a)、(b)に示す波形は、図4(a)、(b)に比べ、10Hzより大きい周波数のノイズが減衰され、平滑化されていることがわかる。ところが、ドア開閉による圧力変化を示す図6(b)における点線の領域部分は、その前後の時刻の波形に比べ、強調されてはいない。このことから、ドア開閉の信号とゆらぎの信号は、0.1Hzから10Hzまでの同一の帯域に存在することがわかり、前述の通り単純なフィルタ処理による前処理などではドア開閉に伴う信号部分を特徴抽出することが困難であるといえる。

【0028】**遅延部4とバッファ5

40 上記した前処理部3で高周波ノイズ成分が除去された信号が、遅延部4に与えられる。この遅延部4は、前信号処理部3で離散化されたデータに対して、1ブロックで1データ分の遅延動作を行うものである。そして、それらデータ群を一時的にバッファ5で保存するようにしている。つまり、バッファ5には、現在から過去数回分の前処理後の信号（瞬時値）が常時格納され、その格納されたデータは、サンプリングタイプごとに時々刻々と変化する。

【0029】すなわち、時刻 z での電圧値を $v(z)$ 、サンプリング周期を T とするとバッファ5内のデータは、

【0030】

【数1】

$$\begin{matrix} 7 \\ [v(z-T), v(z-2T), v(z-3T), \dots, v(z-pT)] \end{matrix}$$

が保存されることになる。ここで、 p はバッファが保存できるデータ数(容量)を表している。なお、本実施の形態では、 $T=10\text{ms}$ 、 $p=10$ としている。

＊＊特徴量計算部6

特徴量計算部6は、バッファ5に格納されているデータ(サンプル値)を用いて、複数の特徴量を計算するものである。特徴量の種類としては、統計量、情報量、直交関数の係数、データに重みを掛けた係数、ユーザが独自に定義した量やその他、バッファのデータから計算される量なら何でも良く、以下にそれらの例を示す。

(A) 統計量としては、平均値、中央値、分散、標準偏差、 k 次モーメント、波形率、波高率、歪度、尖度などがある。

(B) 情報量としては、エントロピー、カルバック情報量などがある。

(C) 直交関数の係数としては、フーリエ変換の係数、ウェーブレット変換の係数などがある。

(D) データに重みを掛けた係数としては、自己回帰モデル(ARモデル)、自己回帰移動平均モデル(ARMAモデル)の各係数などがある。

(E) ユーザが独自に定義した量としては、しきい値越え回数、しきい値越え時間、平均ピークTOピーク値、極小値数、傾き平均値などがある。

$$\{ (v_4 + v_6 + v_8) / 3 \} - \{ (v_2 + v_5 + v_7 + v_9) / 4 \}$$

により計算される。

【0034】極小値数とは極小値の数であり、極小値は前記に示した方法で求める。傾き平均値とは、各データ※

$$\{ (v_9 - v_8) + (v_8 - v_7) + \dots + (v_1 - v_0) \} / 9$$

である。

【0036】そして、本実施の形態では、特徴量にFFT(フーリエ変換の振幅成分)を用いた。バッファ5で保存されている10ポイントのデータからFFTを求めると、振幅成分として5個の特徴量が求まる。この計算の様子を図8、図9に模式的に示す。図8中L1は、前信号処理部3から得られる波形の信号中心であり、左から右へ時刻が進む。また、図中の黒点は、サンプルしたデータを表し、その黒点を結ぶ折れ線は波形を示している。例えば、ある時刻に区間abの10点のデータがバッファ5に保存されているとする。このとき特徴量計算部6では、その10点のデータに基づくFFTによって、図9に示される5つの周波数成分の振幅値が求められる。

【0037】次のデータがサンプルされると区間cdのデータ、その次には区間efのデータ、というように順々に特徴量が求められていく。なお図9で示すグラフは横軸が周波数、縦軸が振幅値である。これら5つの特徴量が自己組織化装置8の入力ベクトルとして用いられる。

【0038】自己組織化装置8とメモリ7

※【0031】そして、上記の「(E) ユーザが独自に定義した量」にあげた例の詳しい説明をすると以下のようになる。まず、図7に波形の1部を模式的に示す。図において、L1が信号中心であり、黒点が各サンプリングデータであり、一点鎖線は任意に設定されたしきい値 T_h を示している。この前提に立ち、例えばある時刻において、バッファ5内に図7の区間abに示される10個のデータが保存されていたとする。さらに各データに $v_0 \sim v_9$ という電圧値が測定されたとする。

【0032】しきい値越え時間は、しきい値 T_h を超える v_4 、 v_6 、 v_8 が測定される時間 $30\text{ms} = (\text{しきい値を越えたデータ数}) \times (\text{サンプリング時間})$ を表す。しきい値越え回数とはしきい値を越える回数であり、この例では3である。平均ピークTOピークとは、区間ab内で極大値の平均と極小値の平均の差のことである。ここで極大値は正の変化から負の変化へ転じる点、すなわち、 v_4 、 v_6 、 v_8 であり、極小値は負の変化から正の変化へ転じる点、すなわち、 v_2 、 v_5 、 v_7 、 v_9 を表す。したがって、平均ピークTOピークは、

【0033】

【数2】

※間の電圧差を計算し平均する。すなわち、

【0035】

【数3】

30 メモリ7は自己組織化装置8の出力結果(参照ベクトル)を保存する記憶装置である。自己組織化装置8の動作を説明する前に自己組織化について簡潔に説明する。【0039】人間の脳内における神経ネットワークの自己組織化現象に対する工学的モデルの最も単純な形式として、T. Kohonenは「自己組織化マップ」というアルゴリズムを発表している(T. Kohonen著、徳高・岸田・藤村訳、「自己組織化マップ」(シュブリンガー・フェアラーク東京株式会社))。このアルゴリズムは、ニューラルネットワークの学習方法の1つである競合学習に分類される。これは、高次元の入力データを1次元あるいは2次元程度の低次元空間に写像するものであり、出力データは入力データの密度が反映された広がりになく対応し、さまざまな情報を取り出すことができる。

【0040】本実施の形態では、1次元の自己組織化マップを用いた。以下に、実際のデータに対して、自己組織化学習を行った例をもとに動作説明をする。図10に自己組織化装置8を模式的に示した。同図に示すように、自己組織化装置8は、入力層と自己組織化層に分けて把握できる。入力層には n 個のニューロン、自己組織

化層にはm個のニューロンがある。

【0041】そして、入力層にはn個の要素を持つベクトル $X = [x_1, x_2, \dots, x_i, \dots, x_n]$ の各要素が各ニューロン1つに入力される。つまり、1番目のニューロンには x_i が入力される。また、自己組織化層のj番目のニューロンに対して全ての入力層のニューロンが重み $w_{j1}, w_{j2}, \dots, w_{jn}$ ($i=1, 2, \dots, m$)で結合している。したがって、全ての自己組織化層には入力層から重みを介して入力が伝わるので、自己組織化層の各ニューロンには内部状態 $w_j = [w_{j1}, w_{j2}, \dots, w_{jn}]$ がある。ここで w_j は参照ベクトルと呼ばれる。よって、入力ベクトル x の分布は、m個の参照ベクトル w_j ($j=1, 2, \dots, m$)

$$w_j(t+1) = w_j(t) + h_{cj}(t) \{x(t) - w_j(t)\}$$

ここで、 $w_j(t)$ 、 $x(t)$ などのtは学習回数を表し、 $h_{cj}(t)$ は、

【0044】

【数6】

$$h_{cj}(t) = \alpha(t) \cdot \exp \left[- \frac{\|r_c - r_j\|}{2\sigma^2(t)} \right]$$

となる。ここで、 $\alpha(t)$ 、 $\sigma(t)$ はtとともに単調に減少する数、 r_c 、 r_j は自己組織化層におけるニューロンの位置ベクトルを表す。そして、この位置ベクトルがL次元のとき、L次元の自己組織化マップと言う。

【0045】参照ベクトルの更新をある決まった回数だけ行くと、学習のために入力された全ての x と w_c (c は x と w_j の距離が最小となるjを表す)との距離の総和は最小になる。つまり、参照ベクトルは誤差が最小となるように、入力ベクトルの分布を近似する。これが自己組織化マップの学習動作である。

【0046】判定動作は、上述したように、ある入力ベ

$$\alpha(t) = \exp \left[- \frac{10}{N} \cdot t \right]$$

$$\sigma(t) = \begin{cases} 0.1 \cdot m - \frac{0.09 \cdot m}{0.5 \cdot N} \cdot t & (t \leq 0.5 \cdot N) \\ 0.01 \cdot m & (t > 0.5 \cdot N) \end{cases}$$

この条件をもとに図5の波形で0～30秒までのデータ(定常状態のデータ)に対して学習を行い、自己組織化マップを求めると、図11と図12に示すような結果が得られる。すなわち、図11は折れ線グラフの左横に記載してある縦の数字が参照ベクトルの番号であり、各折

※m)で近似される。また、自己組織化層の出力 y は、 x と w_j の距離が最も近い w_c のニューロンのみが $y=1$ となり、その他は $y=0$ となる。このとき w_c の選ばれ方は、

【0042】

【数4】

$$\|x - w_c\| = \min \{ \|x - w_j\| \}$$

のとき、m個の w_j の1つが w_c として決まる。そして、参照ベクトルは以下のように更新される。

【0043】

【数5】

$$w_j(t+1) = w_j(t) + h_{cj}(t) \{x(t) - w_j(t)\}$$

※クトルに対してそれに最も距離が近い参照ベクトルを選び、その選ばれたニューロンの出力を1とし、それ以外を0とする。これを利用し、自己組織化マップはパターン認識などに応用されている。

20 【0047】ここで、本実施の形態における自己組織化装置8は、上記の自己組織化マップを用いている。このT. Kohonenのモデルは最も単純に実現できるため用いたのであり、これ以外に実現できればそれを用いても良い。例えば、Willshaw・Malsburgのモデル(中野馨著、「ニューロコンピュータの基礎」(コロナ社))で自己組織化を行うこともできる。

【0048】本実施の形態では、1次元の自己組織化マップを用い、入力層を $n=5$ 、自己組織化層を $m=30$ とし、上記の式③で $\alpha(t)$ 、 $\sigma(t)$ を以下のようにした。ここで、nは学習の総回数を示し、mは参照ベクトルの数、tは0～Nまでの整数とした。

【0049】

【数7】

れ線グラフの横軸が参照ベクトルの要素、縦軸がその大きさを表している。

【0050】折れ線の形状は学習によって得られた参照ベクトルのパターンを示し、番号が増えるにしたがい連続的に変化している様子がわかる。そして、メモリ7に

はこの図 11 で示される各数値データが保存される。なお参照ベクトルの初期値には乱数を与えた。

【0051】図 12 は横軸が入力ベクトルの第 1 要素である x_1 、縦軸が第 2 要素である x_2 であるとき、入力データの分布を小さい点でプロットし、四角い空白の点とそれを結ぶ折れ線で参照ベクトルの 1 次元の自己組織化マップを表している。実際に入力ベクトルは 5 個の要素をもち、これをすべて用いて学習したが、図示の便宜上その内の 2 つの要素だけを示しているが、実際には多次元空間となる。そしてこの図 12 は、入力ベクトルの分布に対し、参照ベクトルの自己組織化がどのように形成されたかを図示したものである。このとき参照ベクトルは入力データとの距離が最小となるように分布している。

【0052】＊距離計算部

距離計算部 9 は実際の判定の際に用いられる（学習のときには用いない）。すなわち、特徴量計算部 6 を通過した新たに入力される判定対象の入力ベクトル x' に対して、メモリ 7 に保存された学習モードで得られた参照ベクトル群の中で距離が最小のものを自己組織化装置 8 の式①によって見つけ、それとの距離を距離計算部 9 で計算する。

【0053】すなわち、距離計算部 9 から出力される量 d は、入力ベクトルを x' 、自己組織化装置 8 の式①から求められた参照ベクトルを w_c とすると、

【0054】

【数 8】

$$d = \|x' - w_c\|$$

となる。さらに、式⑥を正規化することにより、絶対値の変動の影響を受けないようにする。この正規化処理は、学習終了時に上記式⑥から x と w_c の距離を記憶しておき、それを d_{end} とする。そして、判定時に得られた d を下記式の右辺に代入することにより正規化した距離を求めることができる。

【0055】

【数 9】

$$d \leftarrow d / d_{end}$$

本実施の形態では、図 5 に示す波形で 30～43 秒までのデータを判定用のデータとして用い、上記式⑥、⑦を用いて正規化した距離 d を計算した。その結果を図 13 (a) に示すようなグラフが得られる。ここで、横軸は時間、縦軸は正規化された d の数値である。これを見ると、38 秒付近で鋭いピークを持つ変化があるのが判り、これが非定常状態であることを示す。

【0056】つまり、定常状態のときに得られたデータに基づいて自己組織化マップを求めているため、その後の定常状態のときに得られた特徴ベクトルは、その自己組織化マップを構成する参照ベクトル群の中のいずれかと必ず距離が近くなるものがある。一方、非定常状態で

は、逆に異なる特徴量を有することから、いずれのパターンとも近いものが無く結果として距離が遠くなる。

【0057】＊＊比較判定部 10

距離計算部 9 の出力は、比較判定部 10 に与えられる。この比較判定部 10 は、定常か非定常かの判断を出力するもので、本形態では、距離計算部 9 から出力される正規化された距離をしきい値 0.5 と比較し、しきい値以上であれば非定常と判断して「1」を出力し、0.5 未満であれば定常と判断して「0」を出力するようにしている。

【0058】よって、距離計算部 9 の出力が図 13 のようになっているとすると、この比較判定部 10 の出力は、図 14 に示すようになり、38 秒付近で非定常と判定することができ、図 6 (b) の 38 秒付近のドア開閉による圧力変化を検出している。この結果から、図 5 のようにゆらぎ変動が激しい場合でも正確にドア開閉の圧力変化のみを検出することができる。

【0059】＊＊出力装置 11

さらに本形態では、出力装置 11 を備えている。この出力装置 11 は、特徴量計算部 6、メモリ 7、自己組織化装置 8、距離計算部 9 の情報を出力したり、コンピュータなどの表示装置に情報を伝送するための通信機能を持つ。具体例を示すと、図 15 に示すようになっている。図において符号 17 がコンピュータとディスプレイである。ディスプレイ上の表示領域 18 がメモリ 7 の出力を表している。また、表示領域 19 が特徴量計算部 6 と自己組織化装置 8 の出力を表している。

【0060】さらに、符号 21 は本発明の信号処理装置であり、ケーブル 20 にてコンピュータ 17 と接続され、上記のようにディスプレイ上に各種の表示をするための情報を送るようにしている。

【0061】さらに、信号処理より装置 21 の表面には、出力装置の一態様である距離の大きさを示すインジケータ 22 を配置する。このインジケータ 22 は、多数に並んだ LED など構成する。また、比較判定部 10 の判定結果を出力するためのスピーカ 23 や、LED 24 も備えている。

【0062】以上の構成を要約すると、学習モードでは、距離計算部並びに比較判定部 10 は動作を停止する。そして、ドアを開閉しない定常状態の中に本装置を設置し、時々刻々と変化するセンサ出力に対して前処理部 3 で所定の前処理を行って得られたデータを過去数回分バッファ 5 に一時的に貯え、そのバッファ 5 に格納されたデータから特徴量計算部 6 で複数個の特徴量を計算し、得られた複数個の特徴量を自己組織化装置 8 に与え、そこにおいて自己組織化マップを作成し、それをメモリ 7 に格納する。これにより、定常状態の波形の特徴が、自己組織化される。

【0063】そして、実際の判定モードでは、特徴量計算部 6 の出力を距離計算部 9 に与え、メモリ 7 に格納し

10

20

30

40

50

た自己組織化マップの中で最も近いパターンのもので選出し、それとの距離を求める。すると、判定モードで抽出した特徴ベクトルが、定常状態のものであるとすると、自己組織化マップの中のいずれかのパターンと近いので距離も短くなるので、比較判定部 10 でしきい値処理をすると、しきい値未満となり、定常状態と判断される。逆に、いずれのパターンとも離れているとすると、距離が遠くなりしきい値以上となる。この場合、定常状態と異なる特徴が発生したと判断でき、非定常状態と判定できる。

【0064】

【発明の効果】本発明によれば、特徴量の計算およびその自己組織化学習により、階層型ニューラルネットワークによる方法の問題点であるニューロン数を決定すること、特徴量の説明のしにくさ、多くの特徴量が簡単に増やせないことなどを解決することができる。すなわち、ニューロン数を決定せずに、第三者に説明しやすい特徴量を用い、簡単に特徴量の数を増やすことができる。

【0065】また、請求項 2 の発明によれば、定常状態は通常センサである対象を観測している状態であり、それを学習することは最も簡単である。非定常状態はどのような状態か予測が付かないため学習できないが、この事柄も本発明により合理的に解決する。

【0066】さらに、請求項 3 の発明によれば、自己組織化された参照ベクトルは、学習した特徴ベクトルの分布を誤差が最小となるように（ユークリッドノルムによる距離が最小となるように）近似されるため、両者の距離としてユークリッドノルムを用いると、定常状態に属すかどうか簡単に判る。したがって、非定常状態を的確に弁別できる。

【図面の簡単な説明】

【図 1】本発明の一実施の形態による信号処理装置の機能ブロック図である。

【図 2】圧力センサの一例を示す図である。

【図 3】同上実施の形態を説明するための状態信号の波形図である。

*【図 4】同上実施の形態を説明するための信号処理過程での波形図（その 1）である。

【図 5】同上実施の形態を説明するための信号処理過程での波形図（その 2）である。

【図 6】同上実施の形態を説明するための信号処理過程での波形図（その 3）である。

【図 7】同上実施の形態を説明するための信号処理過程での波形図（その 4）である。

【図 8】同上実施の形態を説明するための信号処理過程での波形図（その 5）である。

【図 9】同上実施の形態を説明するための信号処理過程での波形図（その 6）である。

【図 10】同上実施の形態における自己組織化の概念を示す説明図（その 1）である。

【図 11】同上実施の形態における自己組織化の概念を示す説明図（その 2）である。

【図 12】同上実施の形態における自己組織化の概念を示す説明図（その 3）である。

【図 13】同上実施の形態における距離計算の概念を示す説明図である。


【図 14】同上実施の形態における比較判定の概念を示す説明図である。

【図 15】同上実施の形態における出力装置の外観例を示す図である。


【符号の説明】

- 1 センサ
- 2 トランスデューサ
- 3 前処理部
- 4 遅延部
- 5 バッファ
- 6 特徴量計算部
- 7 メモリ
- 8 自己組織化装置
- 9 距離計算部
- 10 比較判定部
- 11 出力装置


【図 3】




(a)




(b)




【図5】




【図6】



(b)




【図12】




特徴量ベクトルの2つの成分
(小さい点がデータの分析を表し、
折れ線が1次元の自己組織化
マップを表す)


【図7】




【図8】




【図9】




【図10】




【図 11】



【図 13】



【図14】



【図15】

